用于农产品冷链物流需求预测的GRA-WHO-TCN组合模型

刘　艳[1*], 季俊成[2]

(1. 深圳信息职业技术学院 财经学院,广东深圳 518000,中国; 2. 澳门理工大学 应用科学院,澳门特别行政区 999078,中国)

摘　要: [**目的/意义**] 为了解决冷链物流需求预测在数字化转型中存在特征提取不充分、数据非线性程度高和算法易陷入局部最优等问题，提出一种结合灰色关联分析（Grey Relational Analysis, GRA）、野马优化算法（Wild Horse Optimizer, WHO）和时序卷积网络（Temporal Convolutional Networks, TCN）的组合预测模型，旨在解决需求预测精度不高的问题，以实现农产品供应链智能化管理。[**方法**] 首先运用GRA对农产品冷链物流相关指标进行关联度筛选；其次采用TCN充分考虑农产品供应链中社会经济数据及物流信息中的时序性特征，并使用WHO对TCN模型超参数进行寻优；最后运用优化的GRA-WHO-TCN模型对浙江省冷链物流需求进行预测。[**结果和讨论**] 采用WHO的时序算法TCN模型能够有效提取多维度数据的时序特征和空间特征，具备较好的拟合效果。与GRA-LSTM、GRA-TCN和GRA-WHO-LSTM模型相比，GRA-WHO-TCN冷链物流需求预测模型具有较低的均方根误差值（11.3）和有效的相关系数（0.95），且预测2016—2020年浙江省农产品冷链物流需求量分别为2 980、3 046、2 487、2 645和2 799万吨，能够实现对冷链物流需求较高的预测精度。[**结论**] 提出的GRA-WHO-TCN模型具备良好的优化和预测能力，能够为数字经济背景下农产品供应链物资流、信息流发展提供科学预测依据和实际参考价值。

关键词: 数字化转型；农产品供应链；冷链物流；灰色关联分析；野马优化算法；时序卷积网络

中图分类号: F326.6;F224　　**文献标志码:** A　　**文章编号:** SA202310006

引用格式:刘艳, 季俊成. 用于农产品冷链物流需求预测的GRA-WHO-TCN组合模型[J]. 智慧农业(中英文), 2024, 6(3): 148-158. DOI：10.12133/j.smartag.SA202310006

LIU Yan, JI Juncheng. GRA-WHO-TCN Combination Model for Forecasting Cold Chain Logistics Demand of Agricultural Products[J]. Smart Agriculture, 2024, 6(3): 148-158. DOI：10.12133/j.smartag.SA202310006 (in Chinese with English abstract)

0　引　言

随着大数据、云计算和智能物流等数字技术的快速发展[1-3]，传统农业向数字化转型建设成为必然趋势。农产品供应链也展现出了数字化特征。农产品生产、供应、运输、分配、需求、营销等交互影响的环节在数字技术赋能下，使得建成数字采集、需求预测、实时监控、动态调配的数字化供应链体系成为可能[4,5]，进而实现农产品供应链管理全环节的效率提升、成本节约和“以需定产、柔性生产”的数字化管理目标[6,7]。冷链物流需求预测作为农产品供应链数字化的重要环节，其需求量同样受到社会经济、基础建设、人文环境和交通运输等各方面因素影响。因此准确预测冷链物流需求对于缓解农产品供应链供需矛盾、提高冷链物流运输效率、增强供应链管理科学性和提升数字化具有重要意义。

针对农产品冷链物流需求预测，目前主要以多元线性回归模型、灰色预测模型、马尔可夫链、支持向量机（Support Vector Machine, SVM）、数据包络分析（Data Envelopment Analysis, DEA）、人工神经网络等方法为主[8-10]。张喜才和李海玲[11]使用灰色-马尔可夫链组合模型对京津冀农产品冷链物流需求进行了预测和分析，预测精度较单一模型有较大程度提升。王晓平和闫飞[12]构建了以农产品供应链、社会经济、冷链发展、人文和物流5个因

收稿日期：2023-10-09

基金项目：广东省教育科学规划项目（2022GXJK588）；教育部人文社科青年基金项目（21YJC790013）

*通信作者：刘 艳，博士，讲师，研究方向为智慧农业。E-mail：2016000074@sziit.edu.cn

素相关的冷链物流需求预测模型，采用适用于高维数据识别的SVM方法进行需求预测，为冷链物流规划提供了解决方案。刘艳利和伍大清[13]采用主成分分析法对冷链物流指标进行降维，并结合BP神经网络对水产品冷链物流需求量预测，对实际冷链物流建设提出了发展策略。陈谦等[14]针对冷链运输中的温度预测问题，采用门控循环网络（Gated Recurrent Unit, GRU）充分挖掘温度时序特征，对提高冷链运输储藏监控效能发挥重要作用。Tomlin[15]对影响农产品冷链物流因素建立权重矩阵，得出农产品冷链物流有向导图。Amorim和Almada-lobo[16]通过探究生鲜农产品和配送成本关系，建立多属性决策模型。Abada和Aggarwal[17]从运输费用角度出发，建立了冷链物流运输成本与需求量的定价模型。Wang和Bessler[18]使用向量自回归模型对肉类需求量进行预测，取得较好效果。

以上研究虽然在冷链物流预测分析采用了相关单一或组合模型，但仍存在以下不足：1）影响冷链物流的因素呈现高度非线性特点，数据离散程度大，采用灰色模型无法准确拟合非指数型数据序列；2）在影响冷链物流的各种因素中，农产品历史数据具有时间连续性和各因素间的空间交联性，但采用灰色-马尔可夫链组合模型和SVM等方法不能有效提取复杂系统的时空特征，影响农产品需求预测的准确性；3）在数字经济背景下，农产品冷链物流需求研究中缺乏对数字技术和数据要素影响因素分析，数农融合高速发展下农产品冷链物流展现出新特征，数字化基础设施建设、数字人才规模和数字化生产等技术因素的出现正对农产品冷链物流需求赋能发展。为弥补以上研究存在数据非线性程度高、时序特征挖掘不充分和数字化技术因素缺乏等不足，本研究首先充分考虑农产品冷链物流运输中数字化建设影响因素，采用灰色关联度分析（Grey Relational Analysis, GRA）筛选关联度高的影响因素加入预测模型；其次利用时间卷积网络（Temporal Convolutional Network, TCN）滑动提取数据中时间序列和空间序列交联特征，并使用野马优化算法（Wild Horse Optimizer, WHO）对模型全局最优参数进行搜索；最后使用优化的GRA-WHO-TCN模型对浙江省农产品冷链物流需求量进行预测分析，为数字农业背景下农产品供应链管理提供决策参考。

1 模型介绍与构建

1.1 GRA灰色关联度分析

为提高农产品冷链物流需求预测准确性，采用灰色关联分析筛选出关联度影响高的因素作为输入放入预测模型中，选取$X=[X_1, X_2, \cdots, X_i]$，$n=1, 2, \cdots, i$，$X$为自变量，农产品物流需求量$Y$为因变量，计算各因素与农产品冷链物流需求之间的灰色关联度。

1）采用min-max方法对数据进行归一化处理，以消除量纲带来的误差，计算方法如公式（1）所示。

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \tag{1}$$

式中：x为原始数据各特征；x_{min}为原始数据各特征中最小值；x_{max}是原始数据各特征最大值；x_{norm}是经归一化处理后的数据。

2）计算灰色关联系数$\xi_i(k)$，计算方法如公式（2）所示。

$$\xi_i(k)=\frac{\min_i \min_k |x_0(k)-x_i(k)| + \rho \max_i \max_k |x_0(k)-x_i(k)|}{|x_0(k)-x_i(k)| + \rho \max_i \max_k |x_0(k)-x_i(k)|}$$
$$k=1, 2, \cdots, n \tag{2}$$

式中：ρ为分辨系数，取0.5；n为因素个数。

3）计算各个影响因素的灰色关联度，计算方法如公式（3）所示。

$$r_i = \frac{1}{n}\sum_{i=1}^{n}\xi_i(k) \tag{3}$$

式中：r_i是第i个特征的灰色关联度值。

1.2 时序卷积神经网络(TCN)

TCN是一种将捕捉低维特征和输入高维时域分类器两个过程融合在一起，创造性地结合因果卷积、膨胀卷积和残差结构的神经网络模型[19]，能够在网络残差结构的基础上利用因果卷积模块保留长时间历史数据的特征。结构如图1所示。

1.3 野马优化算法

野马优化算法是由Iraj Naruei于2021年提出的智能群优化算法[20]。该算法将一个具有d维变量的寻优问题定义为：具有d类不同马群占领栖息地，最终能占领栖息地的马匹为最优解。

首先将马群分为G组，定义如公式（5）所示。

$$G = N \times PS \tag{4}$$

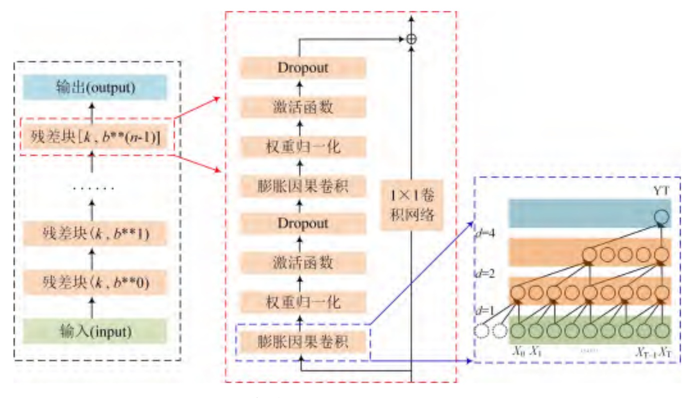


图1 时序卷积神经网络结构图

Fig. 1 Structure of temporal convolutional networks

式中：N为马群的马匹数；PS为种马占马群总数的百分比。通过对PS的控制，可调整划分的组数。划分的每组均有一匹领头马，即种马，其余马匹（$N-G$）平均划分至各组。

1.3.1 放牧行为

将马群的放牧行为建模为种马放牧区域中心，其余马匹在中心周围吃草，位置更新机制由公式（5）确定。

$$\tilde{X}_{g,i}^{d}=2\theta\cos(2\pi R\theta)\times\left(X_{g;\ \mathrm{Stallion}}^{d}-X_{g,i}^{d}\right)+X_{g;\ \mathrm{Stallion}}^{d} \quad (5)$$

式中：$X_{g,i}^{d}$为第d个马群中第g组的马匹i的当前位置，其中$d=[1, 2, \dots, D]$，D为求解的寻优变量个数；$X_{g;\ \mathrm{Stallion}}^{d}$为第$d$个马群中第$g$组的种马的位置；$R\in[-2, 2]$为均匀分布的随机数；$\theta$为自适应机制，由公式（6）确定。通过$\cos(2\pi R\theta)$可使马匹的活动半径不同，最终可得到更新后的位置为$\tilde{X}_{g,i}^{d}$。其中，自适应机制$\theta$由公式（6）确定。

$$\begin{cases}\boldsymbol{P}=R_1<TDR;\\ IDX=(\boldsymbol{P}==0);\\ \theta=R_2\cdot IDX+R_3\cdot(\sim IDX)\end{cases} \quad (6)$$

式中：$\boldsymbol{P}$为0和1组成的一个向量，长度为D，即等于变量的维度；R_1和R_3为[0，1]随机数序列，长度也为D；R_2为[0，1]的随机数；IDX表示满足$\boldsymbol{P}=0$的R_1序列中元素的索引；TDR为一个自适应参数，由公式（7）确定。

$$TDR=1-iter\times\left(\frac{1}{maxiter}\right) \quad (7)$$

式中：$iter$为当前迭代次数；$maxiter$为算法的最大迭代次数。

1.3.2 交配行为

野生马群在交配繁衍过程中有马群的交配行为。其繁衍的子代k需离开进行繁衍。每个马群个体均进行公式（8）表示的交配行为。

$$X_{g,k}^{p}=Crossover\left(X_{g,i}^{q}, X_{g,j}^{m}\right) \quad (8)$$

式中：$X_{g,k}^{p}$为组k中马驹个体p离群后再次进入组k的个体位置；$X_{g,i}^{q}$为组i中个体q离群后再次进入组i的个体位置；$X_{g,j}^{m}$为组j中马驹个体m离群后再次进入组j的个体位置（$i\neq j\neq k$，$p=q=end$）；$Crossover(\cdot)$为与平均型算子相同的函数。各组均重复进行类似马驹q和马驹m交配行为，子代进入另一组。显然，$X_{g,i}^{q}$，$X_{g,j}^{m}$为父母的位置。

1.3.3 领头马位置的确定和替换

领头马带领其群体寻找栖息地，且不同组的领头马相互竞争占领栖息地，此过程描述为公式（9）。

$$\tilde{X}_{g;\ \mathrm{Stallion}}=\begin{cases}2\theta\cos(2\pi R\theta)\times\left(X_H-X_{g;\ \mathrm{Stallion}}\right)+X_H, \text{ if } R_4>0.5\\ 2\theta\cos(2\pi R\theta)\times\left(X_H-X_{g;\ \mathrm{Stallion}}\right)-X_H, \text{ if } R_4\leqslant 0.5\end{cases} \quad (9)$$

式中，$\tilde{X}_{g;\ \mathrm{Stallion}}$为第$g$组的下一领头马的位置；$X_H$为栖息地的位置；$X_{g;\ \mathrm{Stallion}}$为第$g$组当前领头马的位置；$\theta$为公式（6）求得的自适应机制参数；$R$为[－2，2]的均匀分布的随机数值；$R_4$为[0，1]的随机数。

在算法后期，领头马的选择则由适应函数值来确定，替换位置更新机制如公式（10）所示。

$$X_{g;\ \mathrm{Stallion}}=\begin{cases}X_{g,i}\ \ , F\left(X_{g,i}\right)<F\left(X_{g;\ \mathrm{Stallion}}\right)\\ X_{g;\ \mathrm{Stallion}}, F\left(X_{g,i}\right)>F\left(X_{g;\ \mathrm{Stallion}}\right)\end{cases} \quad (10)$$

式中：$F(*)$为适应度函数。

1.4 GRA-WHO-TCN模型构建

组合的GRA-WHO-TCN模型构建过程如下：首先运用GRA灰色关联分析法对农产品冷链物流需求因素指标进行筛选，将关联程度较高的指标作为TCN时序卷积网络模型的输入，并同时采用野马优化算法WHO对时序卷积TCN模型的参数进行智能寻优，使模型具备跳出局部最优的能力，最后将组合模型对农产品冷链数据进行拟合预测。

1.5 农产品冷链物流需求分析流程

首先根据GRA方法选取出与农产品冷链物流需求关联度较高的影响因素；其次采用WHO算法对TCN的超参数TCN层层数、Dense层层数、残差块数量、Dense层神经元个数和TCN层滤波器个数

进行寻优；最后将最优的超参数带入TCN对农产品冷链物流需求进行预测，主要步骤如下。

Step 1：采用min-max方法对影响农产品冷链物流需求因素进行归一化处理；

Step 2：采用GRA对农产品冷链物流影响因素进行关联度分析，选取关联度高的影响因素；

Step 3：将处理的数据进行滑动窗口划分，分别形成训练集和测试集；

Step 4：对WHO算法对种群进行随机初始化，以TCN超参数形成种群；

Step 5：计算适应度目标函数，本实验以均方根误差（Root Mean Squared Error, RMSE）评价指标为目标函数；

Step 6：根据公式（7）计算自适应参数TDR；

Step 7：根据公式（6）计算自适应参数θ；

Step 8：取随机数$Rand$并判断是否大于交配概率PC，如果满足，采用公式（5）更新位置，否则采用公式（8）更新位置；

Step 9：更新种马位置，重新确定领头马。判断是否变量种群中每个个体，“是”则利用公式（9）更新当前种马位置和适应度值，并利用公式（10）重新确定新的领头马位置，“否”则继续执行Step 7；

Step 10：算法终止，并输出最优解，得到最优的搜索参数并带入TCN重新训练，并将优化后的TCN对农产品冷链物流需求进行预测。

2　农产品冷链物流需求预测实证分析

2.1　数据来源

浙江省作为全国典型的农产品主销区，在数字化技术赋能下，农产品冷链物流预测成为农产品供应链管理中面临的重要问题。本研究根据2000—2020年《浙江省统计年鉴》《中国冷链物流发展报告》和《中国统计年鉴》获得农产品冷链物流有关浙江省农业生产、经济发展和人文等20个省份面板数据作为初始数据，并进一步运用GRA方法进行筛选和分析。

2.2　影响因素选取与分析

浙江省农产品冷链物流需求影响因素兼具复杂性和高维非线性，包括但不限于经济规模、仓储物流、人口因素、冷链技术和市场供应等，在数字化经济不断发展下，数字化技术作为加速农产品冷链物流发展的重要手段，在农产品供应链管理发挥越来越重要的作用。本研究根据以往学者[21,22]研究得出的影响因素基础上，加入一级指标数字化技术和二级指标人才规模、科研经费投入、邮电业务总量、光缆建设水平和通信设施建设水平，最终得出影响浙江省冷链物流需求的4个一级指标和20个二级指标的指标体系，如表1所示。

生鲜产量很大程度上代表了当地农业发展水平，考虑浙江省对冷链物流运输状况统计较少，结合以往学者[23,24]对于农产品冷链物流需求预测研究基础，本研究对农产品冷链物流需求量Y定义为公式（11）和公式（12）。

$$Y = P \times (1 - \alpha) \tag{11}$$

$$\alpha = \frac{\varepsilon \times N}{P} \tag{12}$$

式中：P为浙江省冷链农产品产量，万吨；α为浙江省农村居民冷链农产品消费系数；ε为浙江省农村居民冷链农产品人均消费量，kg/人；N为浙江省农村居民人口数，万人。

因此，本研究定义下的浙江省农产品冷链物流需求量Y具体数据如表2所示。

2.2.1　经济规模指标

经济规模大小制约农产品冷链物流需求。农产品消费规模取决于消费者需求。经济增长程度影响消费者消费意愿和消费水平。如表3所示，使用浙江省居民消费支出X_1、浙江省社会零售商品总额X_2、浙江省第三产业增加值X_3、浙江省固定资产投资X_4和浙江省商品交易市场成交额X_5这5个指标作为衡量经济规模的指标。

2.2.2　物流运输指标

物流作为农产品供应中最重要的关键步骤，其运输能力、发展规模对农产品冷链物流需求起到至关重要的作用，如表4所示，选择浙江省货运量X_6、浙江省货运周转量X_7、浙江省快递业务量X_8、浙江省交通运输、仓储和邮政业就业人员X_9和民用载货汽车拥有量X_{10}这5个指标表征物流运输行业发展水平。

2.2.3　数字技术指标

数字经济与传统农业融合发展的背景下，数字化基础设施建设和数字人才规模发展等在数字农业背景下冷链物流需求中占据愈发重要的位置，如表5所示，选取数字人才规模X_{11}、科研经费投入X_{12}、邮电业务总量X_{13}、光缆建设水平X_{14}和通信基础设施建设水平X_{15}这6个指标作为影响冷链物流需求的数字技术指标。

表1 浙江省冷链物流需求评价指标体系

Table 1 Evaluation index system for cold chain logistics demand of Zhejiang province

一级指标	二级指标	指标解释
经济规模	居民消费支出/亿元	城乡居民个人和家庭用于生活消费
	社会消费品零售总额/亿元	生活消费品总量
	第三产业增加值/亿元	为生产和人民生活等活动提供各种服务的产业
	固定资产投资/亿元	反映固定资产规模、结构和速度
	商品交易市场成交额/亿元	成交量反映市场供求之间关系,影响市场价格的波动方向
物流运输	货运量/万吨	衡量运输业务量大小
	货运周转量/亿吨公里	运量和运距复合计算的货物总运输量
	快递业务量/亿件	反映快递运输量的大小
	交通运输、仓储和邮政业就业人员/万人	反映交通运输、仓储和邮政行业就业形势
	民用载货汽车拥有量/辆	反映居民消费水平和生活质量
数字技术	数字人才规模/万人	反映数字技术行业研发人才规模
	科研经费投入/亿元	反映投入数字技术行业研发经费投入
	邮电业务总量/亿元	反映居民信息化、数字化方面需求量
	光缆建设水平	长途光缆皮长/面积
	通信基础设施建设水平	信息传输计算机固定资产投资总额
农产品供应	农产品生产价格指数/亿元	反映农产品生产价格水平和结构变动情况
	水产品总产量/万吨	衡量水产品生产总量
	蔬菜总产量/万吨	衡量蔬菜生产总量
	水果总产量/万吨	衡量水果生产总量
	猪羊牛肉产量/万吨	衡量猪羊牛肉生产总量

表2 2000—2020年浙江省农产品冷链物流需求量

Table 2 Cold chain logistics demand for agricultural products of Zhejiang province during 2000 to 2020

年份	需求量Y/万吨	消费系数α	年份	需求量Y/万吨	消费系数α
2000	1 818.5	0.215 4	2011	2 939.7	0.076 2
2001	2 093.7	0.204 3	2012	2 969.2	0.073 6
2002	2 230.0	0.195 1	2013	2 949.5	0.073 2
2003	2 385.2	0.170 1	2014	2 948.3	0.076 4
2004	2 651.5	0.094 5	2015	2 979.4	0.086 4
2005	2 576.4	0.097 8	2016	2 986.0	0.086 6
2006	2 615.5	0.094 1	2017	3 056.4	0.085 7
2007	2 661.7	0.094 0	2018	2 499.1	0.101 9
2008	2 759.6	0.089 8	2019	2 653.7	0.097 0
2009	2 777.3	0.088 9	2020	2 815.4	0.092 2
2010	2 852.3	0.080 7			

2.2.4 农产品供应指标

农产品供给处于农产品供应链的最初阶段，供给是否充足将影响农产品冷链物流运输、分配和销售等各个环节，对农产品冷链物流需求产生持续而复杂的影响。如表6所示，选择浙江省农产品生产价格指数X_{16}、浙江省水产品总产量X_{17}、浙江省蔬菜产量X_{18}、浙江省水果产量X_{19}和浙江省猪羊牛肉产量X_{20}共5个指标作为影响农产品冷链物流需求的供给影响因素。

2.3 GRA-WHO-TCN组合模型验证分析

2.3.1 GRA灰色关联度分析

对所选取的20个指标进行灰色关联度分析。20个冷链物流发展指标与冷链物流需求的关联度排序结果如图2所示，可知，有3个指标的灰色关联度值显著低于0.75且与其他指标偏离，为了更好地理解和预测目标变量，确保所选指标包含足够的信息量，本研究选取0.75作为指标筛选临界值，20个指标中总计有17个指标处于临界值以上，故选取这17个指标：居民消费支出X_1，社会消费品零售总额X_2，第三产业增加值X_3，固定资产投资X_4，商品交易市场成交额X_5，货运量X_6，货运周转量X_7，快递业务量X_8，交通运输、仓储和邮政业就业人员X_9，民用载货汽车拥有量X_{10}，数字人才规模X_{11}，科研经费投入X_{12}，邮电业务总量X_{13}，水产品总产量X_{17}，蔬菜总产量X_{18}，水果总产量X_{19}和猪羊牛肉产量X_{20}作为模型输入参数。

2.3.2 GRA-WHO-TCN模型分析验证

首先将GRA筛选的17个指标数据进行数据预处理，由于经济数据间时序特征明显，考虑TCN

表3　2000—2020年浙江省消费市场经济规模指标

Table 3　Consumer market economy scale indicators of Zhejiang province during 2000 to 2020

年份	居民消费支出 X_1/亿元	社会消费品零售总额 X_2/亿元	第三产业增加值 X_3/亿元	固定资产投资 X_4/亿元	商品交易市场成交额 X_5/亿元
2000	2 334.08	2 513	2 246.7	1 470	4 023.0
2001	2 602.81	2 789	2 677.9	1 872	4 652.0
2002	2 874.66	3 103	3 242.6	2 253	4 997.0
2003	3 338.66	3 435	3 909.3	4 822	5 591.0
2004	3 909.82	3 976	4 517.9	5 935	6 384.0
2005	4 636.46	4 547	5 193.2	6 699	7 173.0
2006	5 584.50	5 234	6 093.9	7 500	8 247.0
2007	6 509.53	6 115	7 547.9	8 323	9 325.0
2008	7 394.05	7 332	8 698.6	9 211	9 794.0
2009	8 320.39	8 415	9 816.7	10 625	10 744.9
2010	9 796.72	10 057	11 936.1	12 265	12 717.3
2011	11 643.89	12 093	14 048.6	14 166	14 500.0
2012	12 496.10	13 668	15 731.1	17 048	15 816.6
2013	13 593.16	15 335	17 453.1	20 151	17 800.0
2014	14 794.82	17 078	18 716.2	23 533	19 500.0
2015	17 047.48	18 910	21 129.8	26 619	20 500.0
2016	18 536.03	20 917	23 792.4	29 466	20 500.0
2017	21 418.72	23 121	27 222.5	31 022	21 500.0
2018	23 789.87	25 162	30 718.8	33 055	21 900.0
2019	25 730.84	27 344	34 075.8	36 442	23 058.2
2020	24 584.04	26 629	36 031.1	38 409	21 239.2

表4　2000—2020年浙江省物流运输规模指标

Table 4　Logistics transport scale indicators of Zhejiang province during 2000 to 2020

年份	货运量 X_6/万吨	货运周转量 X_7/亿吨公里	快递业务量 X_8/亿件	交通运输、仓储和邮政业就业人员 X_9/万人	民用载货汽车拥有量 X_{10}/万辆
2000	55 008	1 199.74	—	—	34.46
2001	55 706	1 371.60	—	—	41.40
2002	63 532	1 616.61	—	—	46.97
2003	70 907	2 047.48	—	—	48.30
2004	78 540	2 701.48	—	23.1	51.86
2005	81 448	3 416.90	0.58	23.5	55.90
2006	89 342	4 363.71	0.72	24.3	59.74
2007	98 742	4 962.38	0.84	24.6	63.81
2008	91 625	5 476.25	0.98	22.1	66.90
2009	95 802	5 659.78	1.47	23.9	76.65
2010	103 394	7 117.04	2.48	25.2	87.29
2011	108 654	8 634.82	4.96	27.4	97.00
2012	113 393	9 183.30	8.19	29.4	105.02
2013	107 186	8 949.57	14.19	31.4	112.36
2014	117 070	9 548.09	24.57	32.7	111.56
2015	122 547	9 868.98	38.31	32.0	104.00
2016	133 999	9 788.76	59.87	31.5	112.87
2017	151 920	10 105.81	79.32	31.8	124.53
2018	166 533	11 538.14	101.10	30.1	136.78
2019	177 683	12 391.92	132.62	31.2	147.47
2020	189 582	12 324.24	179.46	35.2	161.41

注：—为统计值缺省。

能够充分学习数据的空间和时序特征，本研究采用滑动窗口技术对冷链物流需求量指标数据进行划分，利用TCN的空洞卷积和因果卷积优势提取分析数据的相关特征。采取时间步长为2、滑动步长为1的划分方式对冷链物流需求量指标数据进行划分。经济规模指标划分过程如图3所示。

选取2000—2015年数据作为训练集，2016—2020年数据作为测试集。针对算法的优化能力和预测性能分析，采取测度有RMSE、相关系数R。

根据TCN结构参数，设置初始种群个体5个特征选择超参数范围为：TCN层数∊［1，3），TCN结构残差块个数∊［1，5］，TCN层滤波器个数∊［2，64］，Dense层数∊［1，3），Dense层神经元个数∊［32，128）。为测试采用WHO算法寻优TCN的优劣性，同时采取WHO算法对长短期记忆网络（Long Short-term Memory, LSTM）网络寻优，根据两层LSTM网络结构，初始种群个体特征参数选取为3个，L_1层和L_2层神经元个数∊［2，64］，学习率∊［0.001，0.01］，各算法主要初始设置参数如表7所示，单模型训练均采用10次重复训练结果取平均值。

2.3.3　结果分析

表8和表9展示了单网络模型GRA-TCN和GRA-LSTM预测结果。从表9可以看出，两个单模型预测相对误差均较大程度偏离实际结果，预测精度不佳。从表8可看出，GRA-TCN的RMSE为37.34，较GRA-LSTM低17.1，且预测值曲线有较大的波动，效果不够稳定。从相关系数角度看，GRA-TCN模型对于冷链物流数据的拟合能力比GRA-LSTM好，相关系数为0.91，验证了TCN时序模型结构对处理冗杂非线性数据的优势性和有效性。

根据单模型预测结果，分析并比较GRA-WHO-LSTM、GRA-WHO-TCN寻优超参数模型的冷链物流需求量预测结果。GRA-WHO-LSTM模型

表5 2000—2020年浙江省数字技术指标

Table 5 Digital technical indicators of Zhejiang province during 2000 to 2020

年份	数字人才规模X_{11}/万人	科研经费投入X_{12}/亿元	邮电业务总量X_{13}/亿元	光缆建设水平X_{14}	通信基础设施建设水平X_{15}
2000	2.86	36.59	324.08	2.12	—
2001	3.92	44.74	279.90	2.35	—
2002	4.46	57.65	363.43	2.34	—
2003	4.96	77.76	504.72	2.13	—
2004	5.85	115.55	677.17	2.38	106.0
2005	8.01	163.29	830.39	2.55	96.4
2006	10.81	224.03	972.08	2.61	103.1
2007	13.05	286.32	1 327.06	2.63	125.7
2008	16.03	345.76	1 545.42	2.38	135.3
2009	18.51	398.84	1 666.37	2.27	160.1
2010	22.35	494.23	1 971.96	2.29	158.7
2011	26.29	612.93	897.97	2.27	138.4
2012	27.81	722.59	1 024.02	2.37	138.5
2013	31.10	817.27	1 178.60	2.34	138.4
2014	33.84	907.85	1 684.46	2.31	138.5
2015	36.47	1 011.18	2 392.11	2.32	138.4
2016	37.66	1 130.63	3 715.39	2.32	138.5
2017	39.81	1 266.34	3 518.01	2.39	138.4
2018	45.80	1 445.69	6 425.51	2.25	138.5
2019	53.47	1 669.80	9 894.11	2.14	138.5
2020	60.08	1 880.90	12 620.36	2.00	138.5

注：—为统计值缺省。

表6 2000—2020年浙江省农产品供给因素

Table 6 Agricultural products supply factors of Zhejiang province during 2000 to 2020

年份	农产品生产价格指数X_{16}/亿元	水产品总产量X_{17}/万吨	蔬菜总产量X_{18}/万吨	水果总产量X_{19}/万吨	猪羊牛肉产量X_{20}/万吨
2000	—	469.51	1 366.19	380.67	101.57
2001	—	472.85	1 530.64	516.64	111.28
2002	—	480.68	1 672.99	497.79	119.4
2003	101.9	482.82	1 700.94	568.38	122.22
2004	116.8	493.53	1 671.10	632.07	131.72
2005	105.9	483.77	1 663.85	577.96	130.44
2006	102.7	418.01	1 716.61	644.00	108.94
2007	108.6	415.13	1 718.06	690.28	114.50
2008	112.9	398.59	1 755.87	747.92	129.67
2009	100.3	440.31	1 764.76	712.41	130.95
2010	114.8	477.95	1 788.81	701.31	134.90
2011	113.6	515.81	1 815.61	712.36	138.82
2012	104.3	539.58	1 819.81	703.50	142.53
2013	103.0	550.80	1 764.29	715.65	151.89
2014	99.5	575.06	1 762.79	714.84	139.67
2015	102.0	602.00	1 806.94	740.86	111.46
2016	104.5	584.35	1 865.09	724.32	95.64
2017	99.1	594.45	1 910.45	751.29	86.99
2018	100.8	595.71	1 366.19	743.62	77.48
2019	109.9	600.40	1 530.64	744.11	63.73
2020	107.3	615.41	1 672.99	755.27	57.77

注：—为统计值缺省。

的学习率和神经元优化结果如图4a和图4b所示。最优LSTM模型参数为L_1=48，L_2=36，学习率为0.004 3。GRA-WHO-TCN模型的TCN层数、滤波器数量、残差块数量、Dense层数和Dense层神经元个数优化结果如图4c和图4d所示，最优的TCN模型参数为TCN层数为2，残差块数量为2，Dense层数为1，滤波器个数为60个，Dense层神经元为16个。

WHO算法分别对TCN和LSTM模型进行寻优过程适应度变化曲线如图5所示，可以看出在寻优初始阶段，WHO算法有较强能力进行大范围寻优，且GRA-WHO-TCN模型均方根误差始终能够保持较GRA-WHO-LSTM模型更低的值。且从表10可以看出最终寻优结果GRA-WHO-TCN模型RMSE为11.3，低于GRA-WHO-LSTM模型RMSE(14.5)。对比单模型可以看出，WHO寻优算法下的GRA-WHO-TCN和GRA-WHO-LSTM模型RMSE和R均好于单模型预测结果，说明WHO算

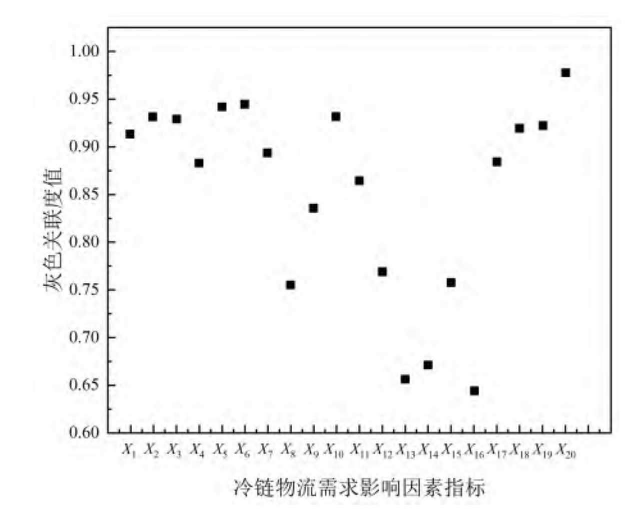


图2 冷链物流需求量影响指标灰色关联度

Fig. 2 Grey correlation degree of impact indicators on cold chain logistics demand

法能够有效对模型参数进行优化，使模型拟合的有效性得到一定程度提升。寻优模型的年份预测结果

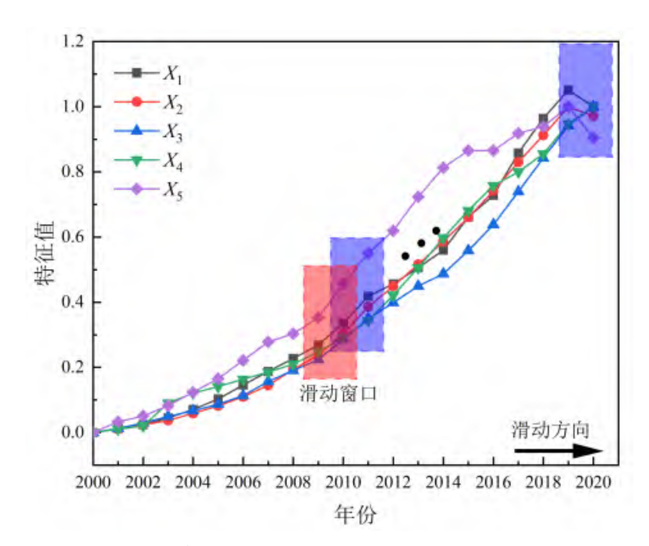


图3　农产品冷链物流数据滑动窗口划分

Fig. 3 Sliding window division of agricultural products cold chain logistics data

表7　GRA-LSTM、GRA-TCN、GRA-WHO-LSTM和GRA-WHO-TCN模型初始参数设置

Table 7 Initial parameter settings for GRA-LSTM, GRA-TCN, GRA-WHO-LSTM, and GRA-WHO-TCN models

网络模型	参数	值
GRA-LSTM	学习率	0.01
	L_1层神经元个数	64
	L_2层神经元个数	32
	Dropout留存率	0.5
GRA-TCN	初始学习率	0.005
	滤波器数量	64
	残差块	5
GRA-WHO-LSTM/GRA-WHO-TCN	初始种群数	50
	最大迭代次数	100
	种马百分比	0.2
	交配率	0.1

表8　单模型预测误差及相关系数

Table 8 Single model prediction error and correlation coefficient

网络模型	RMSE	R
GRA-LSTM	54.44	0.83
GRA-TCN	37.34	0.91

展示如表11所示，可以看出GRA-WHO-TCN模型对2016—2020年冷链物流需求预测的相对误差均小于其余3种算法，对比单模型预测结果，优化后的模型预测性能明显提升，说明利用GRA-WHO-TCN模型能够有效提高农产品冷链物流需求预测的精度和稳定性。基于GRA-WHO-TCN模型，得到

表9　GRA-LSTM和GRA-TCN单模型预测结果

Table 9 GRA-LSTM and GRA-TCN single model prediction results

年份	GRA-LSTM		GRA-TCN	
	预测	误差/%	预测	误差/%
2016	2 943	1.44	3 023	1.24
2017	2 979	2.53	3 113	1.85
2018	2 431	2.72	2 522	0.92
2019	2 640	0.52	2 688	1.29
2020	2 769	1.65	2 789	0.94

2016—2020年浙江省农产品冷链物流需求量预测值分别为2 980、3 046、2 487、2 645和2 799万吨。

3　结　论

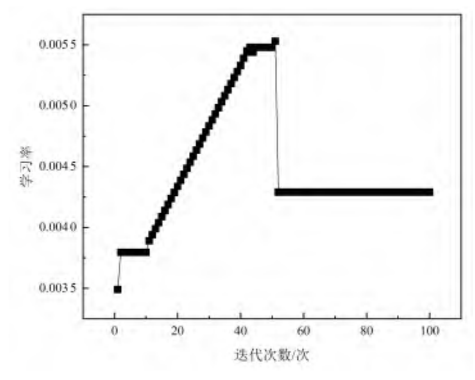
针对数字经济背景下农产品冷链物流需求预测问题，本研究提出GRA-WHO-TCN的冷链物流需求预测方法，得出以下结论：

1）采用GRA灰色关联分析法对2000—2020年浙江省20个冷链需求相关因素指标进行关联度分析，并筛选出涉及经济规模指标、物流运输指标、数字技术指标和农产品供应指标下17个关联度较高的指标，建立浙江省冷链物流需求预测模型指标评价方案。

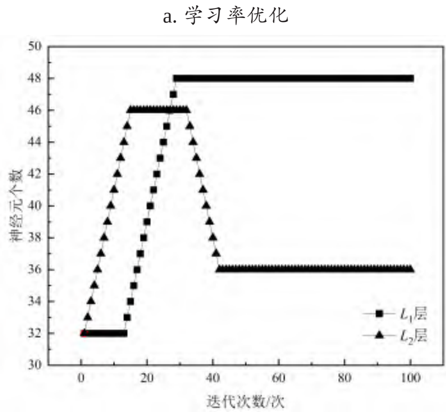
2）运用单模型GRA-TCN和GRA-LSTM分别对建立的农产品冷链物流数据进行需求预测，结果表明，GRA-TCN的计算精确度高于GRA-LSTM，其RMSE较GRA-LSTM模型低17.1，GRA-TCN模型结构对处理分析时序相关和空间关联数据具有明显优势。

3）提出的GRA-WHO-TCN模型寻优超参数过程具备良好跳出局部最优的能力，能够得到较单模型更优的适应度值，GRA-WHO-TCN模型的RMSE（11.3）低于GRA-WHO-LSTM模型RMSE（14.5），对于农产品冷链物流需求预测结果拟合度较好，预测2016—2020年浙江省农产品冷链物流需求量分别为2 980、3 046、2 487、2 645和2 799万吨，与实际值相对误差保持在0.6%以内。由此可见，本文建立的GRA-WHO-TCN组合模型对农产品冷链物流需求预测有较好的预测精度，具有一定的指导和参考价值。

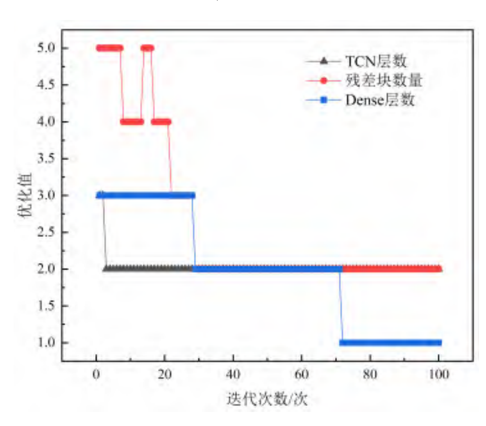
本研究提出的算法对农产品供应链中农产品需求环节进行预测，但未建立对农产品供应链生产、分配、运输和销售等多环节预测的模型。在未来研究中，将考虑融入农产品产地信息、销售地信息、



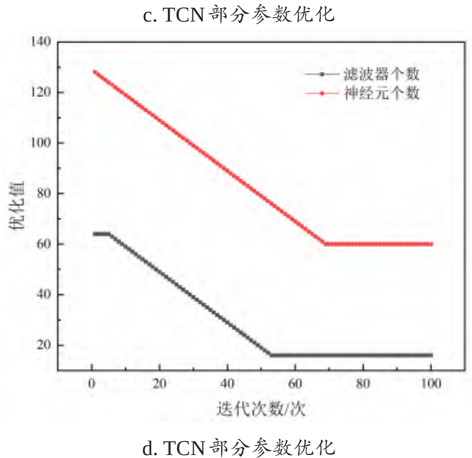
a. 学习率优化



b. 神经元优化



c. TCN部分参数优化



d. TCN部分参数优化

图4 LSTM网络和TCN参数优化结果

Fig 4 Optimization results of LSTM net and TCN parameters

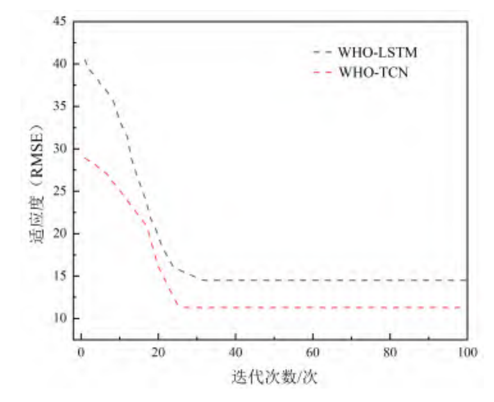


图5 GRA-WHO-LSTM和GRA-WHO-TCN模型适应度变化

Fig. 5 Changes in fitness of GRA-WHO-LSTM and GRA-WHO-TCN models

表10 GRA-WHO-LSTM和GRA-WHO-TCN模型预测误差及相关系数

Table 10 GRA-WHO-LSTM and GRA-WHO-TCN model prediction error and correlation coefficient

网络模型	RMSE	*R*
GRA-WHO-LSTM	14.5	0.94
GRA-WHO-TCN	11.3	0.95

表11 寻优模型预测结果

Table 11 Optimization model prediction results

年份	GRA-WHO-LSTM		GRA-WHO-TCN	
	预测	误差/%	预测	误差/%
2016	3 000	0.47	2 980	0.20
2017	3 047	0.31	3 046	0.34
2018	2 480	0.76	2 487	0.48
2019	2 640	0.52	2 645	0.33
2020	2 801	0.51	2 799	0.58

运输分配公司信息，建立高维度数据库，运用长时序预测算法实现实时预测能力，以对农业生产、销售等提供有效指导。

利益冲突声明：本研究不存在研究者以及与公开研究成果有关的利益冲突。

参考文献：

[1] 乔良, 张嘉琳. 数字经济背景下农产品供应链发展趋势分析[J]. 中国储运, 2023(1): 125-126.
QIAO L, ZHANG J L. Analysis on the development trend of agricultural products supply chain under the background of digital economy[J]. China storage & transport, 2023(1): 125-126.

[2] 韩慧健, 韩佳兵, 张锐. 基于模糊认知图的物流需求预测模型研究[J]. 系统工程理论与实践, 2019, 39(6): 1487-1495.
HAN H J, HAN J B, ZHANG R. Study on logistics demand forecasting model based on fuzzy cognitive map[J].

Systems engineering-theory & practice, 2019, 39(6): 1487-1495.
[3] MONTANARI R. Cold chain tracking: A managerial perspective[J]. Trends in food science & technology, 2008, 19 (8): 425-431.
[4] JOSHI R, BANWET D K, SHANKAR R. Consumer link in cold chain: Indian scenario[J]. Food control, 2010, 21 (8): 1137-1142.
[5] 孔玉寒, 王雪松, 田政. 集聚冷链物流要素畅通冷链循环通道——加快推进南京冷链物流高质量发展的研究与思考[J]. 物流工程与管理, 2022, 44(7): 28-30.
KONG Y H, WANG X S, TIAN Z. Aggregating cold chain logistics elements, unblocking the cold chain circulation channel: Research and thinking on accelerating the high-quality development of cold chain logistics in Nanjing[J]. Logistics engineering and management, 2022, 44 (7): 28-30.
[6] 章宗标. 一种基于PCA-BP神经网络的示例优选方法[J]. 计算机工程与应用, 2013, 49(19): 108-111, 172.
ZHANG Z B. Optimum selection method of audio sample based on PCA and BP Neural Network[J]. Computer engineering and applications, 2013, 49(19): 108-111, 172.
[7] KALAITZIS P, DIJK G, BAOURAKIS G. Euro-mediterranean supply chain developments and trends in trade structures, in the fresh fruit and vegetable sector[C]// Barcelona, Spain: European Association of Agricultural Economists, 2007.
[8] YA B. Study of food cold chain logistics demand forecast based on multiple regression and AW-BP forecasting method on system order parameters[J]. Journal of computational and theoretical nanoscience, 2016, 13(7): 4019-4024.
[9] 王晓平, 彭文凯, 卢怀宇, 等. 基于支持向量机模型的北京城镇农产品冷链物流需求预测[J]. 湖北农业科学, 2018, 57(15): 88-94.
WANG X P, PENG W K, LU H Y, et al. Forecast of cold chain logistics demand for agricultural products in Beijing based on support vector machine model[J]. Hubei agricultural sciences, 2018, 57(15): 88-94.
[10] TREBAR M, LOTRIČ M, FONDA I. Use of RFID temperature monitoring to test and improve fish packing methods in styrofoam boxes[J]. Journal of food engineering, 2015, 159: 66-75.
[11] 张喜才, 李海玲. 基于灰色与马尔科夫链模型的京津冀农产品冷链需求预测[J]. 商业经济研究, 2019(15): 109-111.
ZHANG X C, LI H L. Forecast of cold chain demand of agricultural products in Beijing, Tianjin and Hebei based on grey and Markov chain model[J]. Journal of commercial economics, 2019(15): 109-111.
[12] 王晓平, 闫飞. 基于多源信息融合的冷链农产品需求预测模型研究综述[J]. 湖北农业科学, 2018, 57(15): 16-20.
WANG X P, YAN F. Review on demand forecasting model of cold chain agricultural products based on multi-source information fusion[J]. Hubei agricultural sciences, 2018, 57(15): 16-20.
[13] 刘艳利, 伍大清. 基于改进BP神经网络的水产品冷链物流需求预测研究——以浙江省为例[J]. 中国渔业经济, 2020, 38(5): 93-101.
LIU Y L, WU D Q. Research on cold chain logistics demand prediction of aquatic products based on improved BP Neural Network: A case study of Zhejiang province[J]. Chinese fisheries economics, 2020, 38(5): 93-101.
[14] 陈谦, 杨涵, 王宝刚, 等. 基于GRU神经网络模型的冷链运输温度时序预测[J]. 农业大数据学报, 2022, 4(1): 82-88.
CHEN Q, YANG H, WANG B G, et al. Time series prediction of cold-chain transportation temperature based on GRU neural network model[J]. Journal of agricultural big data, 2022, 4(1): 82-88.
[15] TOMLIN B. Capacity investments in supply chains: Sharing the gain rather than sharing the pain[J]. Manufacturing & service operations management, 2003, 5(4): 317-333.
[16] AMORIM P, ALMADA-LOBO B. The impact of food perishability issues in the vehicle routing problem[J]. Computers & industrial engineering, 2014, 67: 223-233.
[17] ABADA P L, AGGARWAL V. Incorporating transport cost in the lot size and pricing decisions with downward sloping demand[J]. International journal of production economics, 2005, 95(3): 297-305.
[18] WANG Z J, BESSLER D A. The homogeneity restriction and forecasting performance of VAR-type demand systems: An empirical examination of US meat consumption[J]. Journal of forecasting, 2002, 21(3): 193-206.
[19] 马佳成, 王晓霞, 杨迪. 基于Attention机制的TCN-LSTM非侵入式负荷分解[J]. 电力信息与通信技术, 2023, 21(8): 43-51.
MA J C, WANG X X, YANG D. Non-intrusive load decomposition based on TCN-LSTM model with attention mechanism[J]. Electric power information and communication technology, 2023, 21(8): 43-51.
[20] NARUEI I, KEYNIA F. Wild horse optimizer: A new meta-heuristic algorithm for solving engineering optimization problems[J]. Engineering with computers, 2022, 38 (4): 3025-3056.
[21] 吴家葆, 曾国辉, 张振华, 等. 基于K-means分层聚类的TCN-GRU和LSTM动态组合光伏短期功率预测[J]. 可再生能源, 2023, 41(8): 1015-1022.
WU J B, ZENG G H, ZHANG Z H, et al. Dynamic combination of TCN-GRU and LSTM photovoltaic short-term power prediction based on K-means hierarchical clustering[J]. Renewable energy resources, 2023, 41(8): 1015-1022.
[22] 郭明德, 李红. 基于PCA-RBF神经网络模型的果蔬冷链物流需求预测[J]. 江西农业学报, 2018, 30(10): 137-141.
GUO M D, LI H. Prediction on cold-chain logistics demand of fruits and vegetables based on PCA-RBF neural network model[J]. Acta agriculturae Jiangxi, 2018, 30 (10): 137-141.
[23] 朱闯, 孙庆峰. 基于MIV-GA-BP模型的农产品冷链物流需求预测[J]. 物流科技, 2023, 46(9): 134-137.
ZHU C, SUN Q F. Demand forecast of agricultural products cold chain logistics based on MIV-GA-BP model[J]. Logistics sci-tech, 2023, 46(9): 134-137.
[24] 刘发国. 南京都市圈农产品冷链物流需求预测及网络布局研究[D]. 太原: 山西财经大学, 2023.
LIU F G. Research on demand forecast and network layout of cold chain logistics of agricultural products in Nanjing metropolitan area[D]. Taiyuan: Shanxi University of Finance and Economics, 2023.

GRA-WHO-TCN Combination Model for Forecasting Cold Chain Logistics Demand of Agricultural Products

LIU Yan[1*], JI Juncheng[2]

(1. *Institute of Finance and Economics, Shenzhen Institute of Information Technology, Shenzhen* 518000, *China*;
2. *Academy of Applied Sciences, Macao Polytechnic University, Macao* 999078, *China*)

Abstract:
[Objective] As a critical component of agricultural product supply chain management, cold chain logistics demand prediction encounters challenges such as inadequate feature extraction, high nonlinearity of data, and the propensity for algorithms to become trapped in local optima during the digital transformation process. To address these issues and enhance the accuracy of demand prediction, achieve intelligent management of the agricultural product supply chain, a combined forecasting model that integrates grey relational analysis (GRA), the wild horse optimizer (WHO), and temporal convolutional networks (TCN) is proposed in this research.
[Methods] Firstly, a cold chain logistics indicator system was established for the data of Zhejiang province, China, spanning the years 2000 to 2020. This system covered four key aspects: the economic scale of agricultural products, logistics transportation, digital technology, and agricultural product supply. Then, the GRA was applied to identify relevant indicators of cold chain logistics for agricultural products in Zhejiang province, with 17 indicators selected that had a correlation degree higher than 0.75. Sliding window technology, a problem-solving approach for data structures and algorithms, suitable for reducing the time complexity of data to a better level and improving the execution efficiency of algorithms, was used to partition the selected indicators. Secondly, the TCN model was employed to extract features of different scales by stacking multiple convolutional layers. Each layer utilized different-sized convolutional kernels to capture features within different time ranges. By utilizing the dilated convolutional module of TCN, temporal and spatial relationships within economic data were effectively mined, considering the temporal characteristics of socio-economic data and logistics information in the agricultural supply chain, and exploring the temporal and spatial features of economic data. Simultaneously, the WHO algorithm was applied to optimize five hyperparameters of the TCN model, including the number of TCN layers, the number of filters, residual blocks, Dense layers, and neurons within the Dense layer. Finally, the optimized GRA-WHO-TCN model was used to extract and analyze features from highly nonlinear multidimensional economic data, ultimately facilitating the prediction of cold chain logistics demand.
[Results and Discussions] For comparative analysis of the superiority of the GRA-WHO-TCN model, the 17 selected indicators were input into long short-term memory (LSTM), TCN, WHO-LSTM, and WHO-TCN models. The parameters optimized by the WHO algorithm for the TCN model were set respectively: 2 TCN layer was, 2 residual blocks, 1 dense layer, 60 filters, and 16 neurons in the dense layer. The optimized GRA-WHO-TCN temporal model can effectively extract the temporal and spatial features of multidimensional data, fully explore the implicit relationships among indicator factors, and demonstrating good fitting effects. Compared to GRA-LSTM and GRA-TCN models, the GRA-TCN model exhibited superior performance, with a lower root mean square error of 37.34 and a higher correlation coefficient of 0.91, indicating the advantage of the TCN temporal model in handling complex nonlinear data. Furthermore, the GRA-WHO-LSTM and GRA-WHO-TCN models optimized by the WHO algorithm had improved prediction accuracy and stability compared to GRA-LSTM and GRA-TCN models, illustrating that the WHO algorithm effectively optimized model parameters to enhance the effectiveness of model fitting. When compared to the GRA-WHO-LSTM model, the GRA-WHO-TCN model displayed a lower root mean square error of 11.3 and an effective correlation coefficient of 0.95, predicting cold chain logistics demand quantities in Zhejiang province for the years 2016－2020 as 29.8, 30.46, 24.87, 26.45, and 27.99 million tons, with relative errors within 0.6%, achieving a high level of prediction accuracy. This achievement showcases a high level of prediction accuracy and underscores the utility of the GRA-WHO-TCN model in forecasting complex data scenarios.
[Conclusions] The proposed GRA-WHO-TCN model demonstrated superior parameter optimization capabilities and predictive accuracy compared to the GRA-LSTM and GRA-TCN models. The predicted results align well with the development of cold chain logistics of agricultural products in Zhejiang province. This provides a scientific prediction foundation and practical reference value for the development of material flow and information flow in the agricultural supply chain under the digital economy context.

Key words: digital transformation; agricultural product supply chain; cold chain logistics; grey relational analysis; wild horse optimizer; temporal convolutional networks

Foundation items: Guangdong Provincial Education Science Planning Project (2022GXJK588); Ministry of Education Humanities and Social Science Youth Fund Project (21YJC790013)

***Corresponding author:** LIU Yan, E-mail: 2016000074@sziit.edu.cn